情绪起伏与消费欲望：从心理到经济的探索

陈思仪[1,2] 康君[1,2] 王甘萍[1,2] 李奕冕[1,2] 朱廷劭[1,2*]

[1]（中国科学院心理研究所 北京 100101）

[2]（中国科学院大学心理学系 北京 100049）

摘要：随着信息化时代的进程不断推进，情绪在消费者决策中的影响力日益增强。近年来，情绪调节逐渐成为塑造消费者行为的重要因素，尤其在年轻群体中表现得尤为显著。本文从心理学和经济学的视角探讨了情绪波动与消费欲望之间的关系。研究基于情绪调节理论，通过扩充情绪词典和分析微博大数据，考察情绪对社会消费品零售总额的影响。首先，本研究结合现有情绪词库和腾讯 AI Lab 中文词向量数据，利用大模型筛选候选词，构建了更贴合当代网络语言的情绪词典。随后，基于该词典对 2010 至 2020 年的微博情绪数据进行面板数据分析，发现积极情绪（如愉悦、良好）显著促进消费增长，而愤怒和悲伤情绪则通过冲动性或补偿性消费拉动消费水平。相比之下，惊恐情绪对消费行为有一定抑制作用。研究结果不仅丰富了情绪与消费行为关系的理论研究，也为市场营销和政策制定提供了重要参考。

关键词：情绪，消费，大模型，面板数据分析

Emotional Fluctuations and Consumer Desire: An Exploration from Psychology to Economics

Chen Siyi[1,2] Kang Jun[1,2] Wang Ganping[1,2] Li Yimian[1,2] Zhu Tingshao[1,2*]

[1] Institute of Psychology, Chinese Academy of Sciences, Beijing

[2] Department of Psychology, University of Chinese Academy of Sciences, Beijing

Abstract: With the ongoing advancement of the information age, the influence of emotions on consumer decision-making has become increasingly significant. In recent years, emotional regulation has gradually emerged as a key factor shaping consumer behavior, particularly among younger populations. This study explores the relationship between emotional fluctuations and consumer desire from both psychological and economic perspectives. Based on emotional regulation theory, the research expands an emotion lexicon and analyzes large-scale Weibo data to examine the impact of emotions on the total retail sales of consumer goods. First, the study integrates existing emotion lexicons with Tencent AI Lab’s Chinese word vector data and uses large models to filter candidate words, constructing an emotion lexicon more aligned with contemporary online language. Subsequently, panel data analysis of Weibo emotional data from 2010 to 2020, based on the expanded lexicon, reveals that positive emotions (such as joy and contentment) significantly promote consumption growth, while anger and sadness drive impulsive or compensatory consumption. In contrast, emotions of surprise and fear tend to suppress consumption behavior. The findings not only enrich theoretical research on the relationship between emotions and consumer behavior but also provide valuable insights for marketing strategies and policy formulation.

Keywords: Emotion, Consumption, Large Models, Panel Data Analysis

1 引言

随着社会经济迅速发展，人们的消费水平逐年提升。伴随信息化时代网络科技的不断发展，人们的消费形式更加多样化，其消费动机越来越受到研究学者的关注。2024 年 5 月，中国消费者协会发布的《中国消费者权益保护状况年度报告》中指出，2024 年除了追求性价比之外，情绪释放将成为影响年轻一代消费者决策的重要因素，也将是今后一个时期新的消费热点。

情绪是人对外界事物感知过程中产生的即时的、感性的心理反应。社交媒体作为现代人获取信息和表达情感的主要平台，情绪的传播在社交网络中尤为突出。我国主流的社交媒体有微信，QQ、微博等，人们借助这类主流的社交媒体平台进行人际构建、加强社会联系，网民可以通过文字、表情符号、图片或者视频来分享和传播自己的生活、想法和经历，表达他们的情绪(臧国全等, 2021)。

消费行为经过漫长的探索，被定义为：在产品或服务过程中，人们为了满足需求所呈现出的具体行为。Engel 等人(1985)将消费行为内容具体化为具体内容情感和认知这两者之间的能动性，具体行为包括：比照、筛选、购买、使用、评估、处理等。情绪在消费者决策过程中扮演着重要角色。Kahneman(2011)指出，个体在进行决策时，常常在潜意识中受到情绪的驱动。积极情绪能够提升消费者的信息处理能力，从而增强他们对新产品的接受度。相反，消极情绪则可能导致消费者依赖于简单的决策规则，并忽略潜在的信息(Lerner et al., 2015)。例如，Rucker 和 Galinsky(2008)发现，感受到积极情绪的消费者更倾向于进行冲动消费，而消极情绪则可能导致消费行为的抑制(Mandel et al., 2017)；Dunn 和 Norton(2013)指出，节日和促销活动所引发的积极情绪能够显著增强消费者的购买意愿。与此同时，消极情绪可能引发消费者的反拒绝行为，即对购买的犹豫和消极反应(Mandel et al., 2017)。

情绪即信息模型认为，人们当前的情绪状态会直接影响他们的行为或反应，而很少关注情绪的来源(Schwarz at al. 1981)。因此即使情绪来源于与当前任务无关的其他因素，人们也会将情绪判定为与当前任务相关。这使得情绪成为重要的信息和线索，能够对决策和行为产生重要影响。现有研究证明，情绪可以通过情绪调节机制对消费者反应产生重要影响。情绪调节理论假设消费者会通过他们的行为或反应来调节当前的情绪状态(Andrade, 2005)。具体而言，情绪调节理论假

设消费者会将当前情绪状态、预期情绪状态以及期望情绪状态三者结合起来考虑并以此引导自身的行为和反应。消极的情绪状态会驱动消费者对其情绪状态进行调节和修复以达到积极的情绪状态，而一旦消费者处于积极情绪状态，他们往往会保护这种情绪状态，并且努力避免消极情绪。因此相对于情绪积极个体，情绪消极个体更有可能采取提升情绪的行动(Salerno, 2014)。在 Chuang 等人(2008)的研究中，对比不同情绪状态下的消费者，通过电影分别启动消费者情绪，分为积极情绪组、消极情绪组和控制组，随后让消费者想象去超市购买五种享受型商品，最后让消费者选择要购买的商品类型，研究发现，被启动消极情绪的消费者在购买的商品种类上更多样化。

在对文本进行情绪分析时，国内外目前主要运用有监督学习和情绪词典分析两种方法。然而由于有监督学习需要大量的数据标注来构成训练数据，会让研究者消耗较多精力，因此部分研究者会使用基于词语计量的文本分析工具，但这种工具会受到所构建词典词语的限制。随着社交媒体和网络语言的迅猛发展，年轻群体中流行的网络用语和新兴情绪表达方式使得传统的情绪词典难以准确识别，因此本研究考虑对现有情绪词典进行扩充，顺应当代网络语言的动态变化，提升情绪分析工具对微博文本的适用性。

因此，本文基于情绪调节理论，在研究一中基于词向量大模型和大语言模型对情绪词典的扩充，研究二中通过获取的微博数据和宏观经济指标进行面板数据分析，深入探讨情绪与消费之间的关系。通过量化分析情绪与消费之间的关系，希望为商家在市场营销策略和产品设计上提供科学依据，同时为政策制定者理解消费趋势提供参考，有助于填补理论研究中的空白，也为实际应用提供新的视角。

2 研究一：情绪词典的扩充

随着互联网技术的迅速发展和社交媒体的普及，大量新的网络用语和创新词汇不断涌现，这些语言变化使得现有情绪词典在情感识别中的适用性受到挑战，尤其是许多词典构建时间较为久远，可能难以准确捕捉用户在社交媒体上的情绪表达。为解决这一问题，本研究在研究一中对现有情绪词典进行扩充，捕捉当代网络语言的动态变化，以提升情绪分析工具对微博文本的适用性。

2.1 词典理论基础

本研究的词典基础为情感词汇本体和微博客基本情绪词库(徐琳宏等，2008；

董颖红等，2015)。情感词汇本体是由大连理工大学计算机学院林鸿飞团队所创建的情感词典。其在国外六大类情感的基础上划分，由于六大类的情感积极情绪只有“乐”，刻画不够细致，因此林鸿飞团队在“乐”的基础上增加了“好”来描述，其通过手工情感分类和自动获取强度两种方法，从情感语料中获取情感信息。微博客基本情绪词库是由南开大学心理学系陈浩团队所创建的情感词典，其相较于其他情绪词典额外加入了微博上带有情绪色彩的网络用语，将情绪分为快乐、愤怒、悲伤、恐惧、厌恶五类。

2.2 词典扩充

2.2.1 基于现有词典的合并

本研究拟以情感词汇本体的七类情绪为词典基础，在此基础上加入微博客基本情绪词库的五类情感词汇，形成基础词典，该基础词典将情绪分为乐、好、哀、怒、惊、惧、恶七类，共包含 27804 个词语，各类情绪词语数量如表 1 所示。

表 1 各词典情绪维度词数

词典名称	乐	好	哀	怒	惊	惧	恶
情感词汇本体	1967	11108	2314	388	228	1179	10282
微博客基本情绪词库	268	NA	180	82	NA	63	125
合并的基础词典	2130	11108	2405	440	228	1208	10285

2.2.2 词典扩充

本研究使用了腾讯 AI Lab 大模型对情绪词典进行扩充。腾讯 AI Lab 于 2021 年 12 月 24 日公开的中文词向量数据包含 800 多万中文词汇，其中每个词对应一个 200 维的向量。相比现有的中文词向量数据，腾讯 AI Lab 的中文词向量着重提升了覆盖率、新鲜度和准确性三个方面，相比已有各类中文词向量大大改善了其质量和可用性(Song et al., 2018)。

对于每个词类下的所有词语，我们将其输入到腾讯词向量模型下，根据其构建的 Annoy 索引找到其对应的五个最近的可替换词。

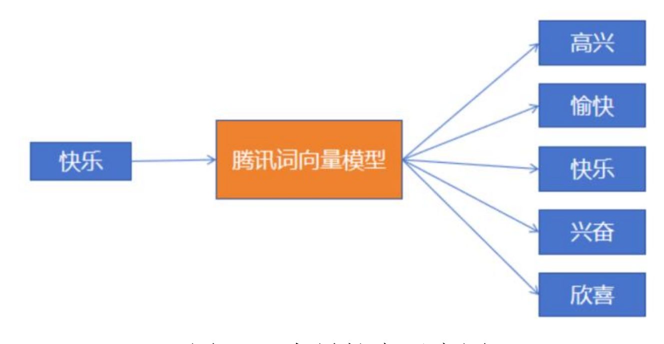


图 1 词向量扩充示意图

随后我们对每一个词类下的所有扩充的可替换词进行统计，若扩充的词语出现频率大于等于两次，我们认为这个扩充的词语很大可能是该词类下的创新词或遗漏词，将其归为候选纳入词列表。

在以往的词典构建或更新中，研究者往往采用人工评判的方法，对于候选纳入词进行评判，该方法会消耗较多的人力资源和时间资源。

随着深度学习和人工智能的快速发展，一种新的问题解决范式——大模型逐渐展现出其非凡的能力。大模型是指使用大规模数据和强大的计算能力训练出来的“大参数”模型，这些模型通常具有高度的通用性和泛化能力，可以应用于自然语言处理、图像识别、语音识别等领域。大模型通过其庞大的参数量、深层次的网络结构和广泛的预训练能力，能够捕捉复杂的数据模式，在多个领域中表现出卓越的性能。它们不仅能够理解和生成自然语言，还能够处理复杂的视觉和多模态信息，适应各种多变的应用场景。大模型具有强大的学习能力和泛化能力，在修改文章、信息识别和情感分析等领域均表现出了较好的水平。

在本研究中，我们希望采用大模型代替人工进行评判，减少时间以及人工成本，我们选取了四个开源大模型作为评判者代替人工编码评判，选取的大模型分别为 qwen2.5:7b、qwen2.5:72b、gemma2:9b、gemma2:27b。

我们构建了 prompt 来让大模型代替人工判断指定的词语是否属于某个词类，对于输出规则，如果大模型认为指定的词语属于这个词类则输出 Y，否则输出 N，为了确保大模型输出内容的信度，我们统计了大模型针对每个词语的五次输出，若其中四次大模型均认为该词属于这个词类，则将该词放入拟纳入词列表。

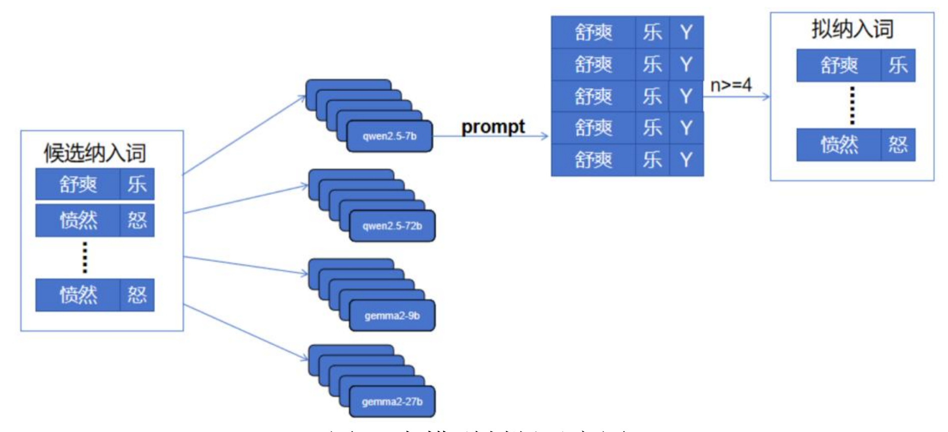


图 2 大模型判断示意图

为判断和量化大模型的信度，我们计算了其对所有词语五次评价的 Fleiss' Kappa 一致性，结果表明大模型多次输出内部结果均具有较好的信度。

表 2　大模型内部评分一致性

模型	qwen2.5:7b	qwen2.5:72b	gemma2:9b	gemma2:27b
信度	0.75	0.82	0.91	0.84

对于获得的拟纳入词列表，若某个词类与词语的组合在该列表中出现了三次及以上，即大于等于三个大模型认为这个词语是属于该情绪词类的，因此可以认为其是经过检验的扩充词，加入之前合并生成的基础词典。

为检验大模型代替人工筛选是否具有较好的效度，我们对于拓展的七类情绪词类每个词类随机选取了 20 个词语进行人工评定，以人工评定的结果作为金标准，构建混淆矩阵进行效度验证。

混淆矩阵是一个方阵，其中行表示实际类别，列表示预测类别，将整个方阵分为四个象限：真正例（True Positive, TP），即模型判定结果为 1，实际编码也为 1 的数量；假正例（False Positive, FP），即模型判定结果为 1，但实际编码为 0 的数量；真负例（True Negative, TN），即模型判定结果为 0，实际编码也为 0 的数量；假负例（False Negative, FN），即模型判定结果为 0，但实际编码为 1 的数量。基于混淆矩阵计算大型语言模型的准确率、精确率、召回率。

图 3 混淆矩阵示意图

2.2.3 结果分析

将大模型的评判结果和人工进行比较，真正例数量为 72，假负例数量为 3，假正例数量为 22，真负例数量为 43。

效度验证结果表明，大模型在情绪词类判断任务中的表现相当优秀。具体来说，大模型的精确率为 0.77，召回率高达 0.96，这表明在识别正例方面，大模型的能力尤为突出，几乎没有漏掉任何正例。这一高召回率表明模型能够有效捕捉到大部分词语情感。另一方面，大模型的准确率为 0.82，进一步表明模型能够在正确判断情绪词类的同时，减少误判断情况，从而在整体判断中维持较高的可靠

性。

此外，F1 分数为 0.85，反映出大模型在精确率与召回率之间保持了较为理想的平衡。F1 分数是精确率和召回率的调和平均，较高的 F1 值表明模型能够在优化正负例识别的同时，兼顾两者之间的权衡。这些验证指标综合展示了模型在情绪词类判断任务中的优异性能。

最终我们对基础情绪词典扩充了 1209 个情感词语。

表 3 各情绪维度扩充词数

	乐	好	哀	怒	惊	惧	恶
情感词汇本体	113	382	196	35	31	81	371

3 研究二

研究二从社会公众的宏观层面深入探究情绪与消费之间的内在关联性本研究采用研究一扩充后的情绪词典，基于大数据的词频统计方式，评估在 2010 至 2020 年社会公众整体呈现出的情绪倾向态势。此外，进一步将公共情绪与社会消费品零售总额构建分析模型，试图挖掘两者之间潜在的量化关系。

3.1 数据来源

研究文本基于 2010-2020 年的微博数据。通过爬虫技术计算出 31 个省级行政单位在 2010-2020 年间的情感倾向。群体消费指标采用国家发布的社会消费品零售总额宏观经济指标（以下简称为“社零总额”）。将源自微博的情绪关注度数据与社零总额数据结合，构成平衡面板数据，并进行面板数据分析。

3.2 描述性统计

使用研究一扩充的七类情绪词典，通过微博数据计算出 31 个省级行政单位在 2010-2020 年间在各个情绪维度的词频。具体结果如表 4。

表 4 各情绪维度词频统计

维度	变量	N	Min	Max
乐	zee x1	341	-2.327	3.065
好	zee x2	341	-4.046	3.349
怒	zee x3	341	-1.970	6.822
哀	zee x4	341	-2.395	3.046
惧	zee x5	341	-1.705	6.982
惊	zee x6	341	-2.723	3.780
恶	zee x7	341	-2.945	2.271

表 5 各情绪维度相关矩阵

	社零总额	乐	好	怒	哀	惧	惊
乐	0.338***						
好	-0.191***	-0.118**					
怒	0.096*	0.316***	-0.0840				
哀	-0.424***	-0.550***	0.389***	-0.247***			
惧	0.0540	0.183***	-0.093*	0.0270	-0.243***		
惊	-0.214***	-0.380***	0.155***	-0.371***	0.697***	-0.294***	
恶	-0.346***	-0.486***	0.411***	-0.303***	0.929***	-0.316***	0.785***

注：* <0.05,** <0.01,*** <0.001

表 6a　7 情绪维度共线性分析

Variable	VIF	1/VIF
zee x7	11.38	0.088
zee x4	8.640	0.116
zee x6	3.070	0.326
zee x1	1.580	0.634
zee x2	1.340	0.747
zee x3	1.260	0.792
zee x5	1.170	0.858
Mean	VIF	4.060

表 6b　6 情绪维度共线性分析

Variable	VIF	1/VIF
zee x4	2.930	0.342
zee x6	2.310	0.432
zee x1	1.560	0.640
zee x3	1.250	0.800
zee x2	1.250	0.803
zee x5	1.120	0.894
Mean	VIF	1.740

相关矩阵和共线性分析见表 5、表 6a 和表 6b，共线性结果显示恶（zee x7）维度的 VIF 值为 11.38，共线程度过高。表 6b 在排除恶维度后，其他维度的 VIF 值均在 3 以下。因此在后续分析中排除恶维度的数据，仅针对 6 个情绪维度数据进行分析。

3.3 构建模型与模型比较

采用以上数据分别构建 OLS 模型、固定效应模型、随机效应模型，具体结果见表 7。

Hausman 检验结果（表 8）表明固定效应模型和随机效应模型之间存在显著差异，固定效应模型最优，模型效果显著优于 OLS 模型和随机效应模型。随机

效应模型显著优于最小二乘回归模型。

表 7 OLS 模型、固定效应模型及随机效应模型

	OLS	固定效应	随机效应
乐	1312.615***	784.421***	822.500***
	(499.903)	(222.845)	(223.950)
好	-247.384	419.290**	387.101**
	(446.271)	(178.905)	(180.207)
怒	-96.930	464.022***	448.441**
	(446.991)	(177.026)	(178.529)
哀	-3567.639***	-220.981	-308.066
	(684.120)	(278.790)	(280.611)
惧	-350.928	152.277	139.983
	(422.827)	(149.194)	(150.718)
惊	1126.673*	-1984.980***	-1878.949***
	(608.109)	(293.604)	(294.288)
cons	9389.284***	9389.284***	9389.284***
	(399.304)	(134.014)	(1248.646)
N	341	341	341
R^2	0.211	0.562	
R^2_a	0.197	0.511	

注：路径系数均为非标准化系数。*p ＜ .05, **p ＜ .01, ***p ＜ .001

表 8 Hausman 检验结果

变量	固定效应
乐	784.4***
	(222.8)
好	419.3**
	(178.9)
怒	464.0***
	(177.0)
哀	-221.0
	(278.8)
惧	152.3
	(149.2)
惊	-1,985.0***
	(293.6)
Constant	9,389.0***
	(134.0)
Observations	341

Number of province	31
R-squared	0.562
Hausman	65.66
p-value	<0.001

注：路径系数均为非标准化系数。*p ＜ .05，**p ＜ .01，***p ＜ .001

3.4 双向固定效应模型

经检验，固定年份及省份后的双向固定效应模型拟合最好，$R2 = 0.635$，调节 $R2 = 0.578$，$F(16, 294) = 32.01$（$p < .001$），corr(u_i, Xb) = -0.168，模型解释了 63.5%的变异，且省份层面的某些特征与情绪存在一定程度的协同变化关系。具体结果如表 9。

表 9 双向固定效应模型

情绪维度	系数	SE	t	P>|t|	95%置信区间	
乐	828.027	378.137	2.19	**0.029**	83.828	1572.225
好	535.311	259.500	2.06	**0.040**	24.597	1046.025
怒	401.784	197.919	2.03	**0.043**	12.266	791.303
哀	1526.346	483.128	3.16	**0.002**	575.519	2477.174
惧	-268.741	278.5277	-0.96	0.335	-816.900	279.417
惊	-1530.734	326.819	-4.68	**0.000**	-2173.935	-887.532
年份						
2011	1198.455	695.165	1.72	0.086	-169.675	2566.586
2012	1098.667	883.616	1.24	0.215	-640.347	2837.681
2013	2660.982	951.905	2.80	**0.006**	787.570	4534.393
2014	2061.048	1036.372	1.99	**0.048**	21.400	4100.696
2015	2009.594	1155.801	1.74	0.083	-265.098	4284.286
2016	3554.860	1549.016	2.29	**0.022**	506.294	6603.426
2017	4884.295	1746.706	2.80	**0.006**	1446.663	8321.926
2018	5341.406	1672.739	3.19	**0.002**	2049.345	8633.467
2019	7011.757	1618.299	4.33	**0.000**	3826.838	10196.680
2020	7517.628	1854.905	4.05	**0.000**	3867.053	11168.200
_cons	5994.858	1075.002	5.58	**0.000**	3879.182	8110.533

3.5 结果分析

通过双向固定效应模型分析发现，不同情绪对社会消费品零售总额有着各异的影响。其中，乐和好的正向情绪能显著促进社会消费品零售总额增长，表明积极情绪对于消费的拉动作用。怒的正向影响表明，愤怒情绪可能导致冲动性消费或宣泄性消费的增加，促使人们购买更多商品以释放压力。哀的正向影响表明，悲伤情绪可能会通过补偿性消费来拉动社会消费品零售总额。惊的负向影响说明，突然性情绪可能导致消费水平的显著降低。恐对消费的影响不显著。

4 讨论

在消费行为的研究中，情绪被认为是影响人们消费决策的重要因素。根据研究结果，正向情绪如乐和好能够显著促进消费，而一些负向情绪既可能导致消费水平的降低，也可能对消费有着拉动作用。

乐和好的正向情绪对消费的拉动作用尤为显著。乐观、愉快和幸福的情绪能够激发人们的消费欲望，并使消费者在购物时更加倾向于做出积极的购买决策。乐观情绪也许能够让个体更愿意投资在满足自己需求和愿望的消费行为上。这种情绪促进的消费不仅仅局限于购买物品，也可能扩展到服务消费、体验型消费等方面。通过这些消费活动，消费者可以获得即时的心理满足和情感释放，进一步加深了积极情绪与消费行为之间的正向循环。

与此同时，良好的情绪状态通常与较高的自我效能感和幸福感挂钩，消费者在处于这些情绪状态下时，会表现出更高的消费意愿和更强的购买动机。这种情绪的激励作用让消费者更容易在购物时做出快速决策，减少了在选择商品时的犹豫和不确定性。更为重要的是，乐和好的情绪还能够降低消费者的风险感知，使其在面对价格较高或非必需品时，依然倾向于做出购买决定。因此，商家如果能够通过提升消费者的情绪状态，例如通过促销活动、情感广告等方式，便能够有效促进销售业绩的增长。

同样地，愤怒的情绪也能对消费产生显著的正向影响。愤怒情绪通常会导致冲动性消费或宣泄性消费的增加。当个体感到愤怒时，他们往往会寻求一种快速的情绪释放方式，消费便成为了他们处理负面情绪的一种途径。愤怒不仅会激发个体的攻击性并导致自我控制力下降，还可能使其产生对冲突和压力的应激反应。因此，愤怒可能促使消费者在没有经过深思熟虑的情况下进行购物，尤其是在情

绪高涨时，容易做出冲动购买行为。

愤怒对消费的正向影响也可以解释为一种宣泄性消费行为，即消费者通过购物来转移注意力，或通过购买物品来弥补自己心理上的不满和愤怒。例如，当人们在工作或生活中遇到挫折或冲突时，购物成为了他们的一种释放压力、重新获得控制感的方式。这种行为不仅促进了商家销售，也缓解了消费者情绪，使其感受到短期的满足感。

此外，悲伤情绪对消费的影响也是正向的。但是与愤怒的宣泄性消费不同，悲伤情绪往往会通过补偿性消费来促进消费。悲伤是一种复杂的情绪，通常与失落、孤独、无力感等负面心理状态相关。当消费者感到悲伤时，他们会寻求一种方式来填补内心的空虚或恢复情绪的平衡，而消费恰好提供了一个潜在的途径。补偿性消费是一种通过购买商品来弥补情感缺失或失望的行为，消费者通过购物带来心理上的慰藉。

这种补偿性消费现象在现代社会中尤为常见，尤其是在面对情感问题、社会压力或重大生活变故时。消费者可能会通过购买奢侈品、享受高端服务，或者选择具有情感共鸣的消费品来获得短期的安慰和心理补偿。在此过程中，商家通过针对情绪低落的消费者推出具有情感价值的商品，能够有效地吸引消费者进行购买，并促进消费品零售总额的增长。

与愤怒和悲伤的正向影响不同，惊则表现出负向影响。惊作为一种突发性和短暂的情绪，通常会让消费者处于一种不确定和焦虑的状态。在这种情绪下，消费者往往会降低他们的消费意愿。尤其是在遇到突如其来的信息或事件时，他们可能对消费产生不安全感或不稳定感。这种情绪造成的不可预测性，使得消费者的消费决策更加谨慎和犹豫，会推迟消费决策，减少不必要的支出。

恐惧是一种强烈的负面情绪，通常也伴随着对未知风险或威胁的感知。然而，本研究结果表明，恐惧情绪并没有显著地影响消费。究其原因，恐惧对消费的影响力可能相对间接，且受其他因素的调节，因此在整体的消费趋势中，恐惧的影响较为微弱。

情绪在消费决策中的作用复杂且多样，不同情绪对消费者的购买行为产生不同的影响。正向情绪，如乐和好，能够促进消费的增长，愤怒和悲伤则通过冲动性消费和补偿性消费拉动消费总额。与此相对，惊和恐的情绪则在一定程度上抑

制了消费行为，尤其是惊的负向影响更为显著。理解这些情绪对消费行为的作用，不仅有助于商家制定更精准的营销策略，也有助于消费者更好地管理自己的消费行为。

参考文献

Andrade, E. B. . (2005). Behavioral consequences of affect: combining evaluative and regulatory mechanisms. Journal of Consumer Research, 32.

Dunn, E. , & Norton, M. . (2013). Happy money. simon & schuster.

Engel, J. F. , Kollat, D. T. , & Blackwell, R. D. . (1985). Consumer behavior. Journal of Marketing, 38(2), 1121-1139.

Kahneman, D. (2011). Thinking, fast and slow. Farrar, Straus and Giroux.

Lerner, J. S. , Li, Y. , Valdesolo, P. , & Kassam, K. S. . (2015). Emotion and decision making. Annual Review of Psychology, 66(1), 799.

Mandel, N. , Rucker, D. D. , Levav, J. , & Galinsky, A. D. . (2017). The compensatory consumer behavior model: how self-discrepancies drive consumer behavior. Journal of Consumer Psychology.

Mandel, N., Lisjak, M., & Wang, Q. (2021). Compensatory routes to object attachment. Current Opinion in Psychology, 39, 55-59.

Mandel, N., Rucker, D. D., Levav, J., & Galinsky, A. D. (2017). The compensatory consumer behavior model: How self‐discrepancies drive consumer behavior. Journal of Consumer Psychology, 27(1), 133-146.

Rucker D D, Galinsky A D, Dubois D. (2012). Power and consumer behavior: How power shapes who and what consumers value[J]. Journal of Consumer Psychology, 22(3): 352-368.

Salerno, A. , Laran, J. , & Janiszewski, C. . (2014). Hedonic eating goals and emotion: when sadness decreases the desire to indulge. Journal of Consumer Research, 41(1), 135-151.

Schwarz, N. , & Clore, G. L. . (1981). Mood, misattribution, and judgments of well-being: informative and directive functions of affective states. Journal of Personality & Social Psychology, 45(3), 513-523.

Song Y., Shi S., Li J., & Zhang H. (2018). Directional Skip-Gram: Explicitly Distinguishing Left and Right Context for Word Embeddings. 175–180. https://doi.org/10.18653/v1/N18-2028

董颖红, 陈浩, 赖凯声, & 乐国安. (2015). 微博客基本社会情绪的测量及效度检验. 心理科学, 38(5), 6.

徐琳宏, 林鸿飞, 潘宇, 任惠, & 陈建美. (2008). 情感词汇本体的构造. 情报学报, 27(2), 6.

臧国全, 孔小换, 张凯亮, & 于政杰. (2021). 社交网络用户自我披露意愿研究——以新浪微博为例. 图书情报工作, 65(16), 8.